



CURSO: Inteligência Artificial para análise de dados geoespaciais baseadas em Redes Neurais Convolucionais (CNNs)

Instrutores:

- Mateus de Souza Miranda (CAP/INPE)

Carga Horária: 16 h

Data: 07 e 08/11/2026 (presencial)

Horário: 8h – 17h

Vagas: 20

Objetivo do curso: Este minicurso, oferecido pelo Laboratório de Inteligência Artificial para Aplicações AeroEspaciais e Ambientais (LIAREA) do INPE, tem como objetivo apresentar os fundamentos e a aplicação prática de técnicas de Inteligência Artificial baseadas em Redes Neurais Convolucionais (CNNs) voltadas ao processamento e análise de imagens de sensoriamento remoto. O curso aborda desde a preparação de conjuntos de dados (datasets) até o treinamento e avaliação de modelos de classificação semântica de imagens, com especial atenção à arquitetura U-Net. Os participantes serão capacitados a desenvolver fluxos de trabalho completos para a classificação de cobertura da terra em imagens de sensoriamento remoto.

Público-alvo: Professores, alunos e profissionais das áreas de Sensoriamento Remoto, Geoprocessamento, Ciência da Computação e áreas afins, interessados em aplicar técnicas de aprendizado profundo para análise de imagens de satélite e aéreas.

Pré-requisitos: Conceitos básicos de programação em Python, noções de álgebra linear e estatística, e familiaridade com imagens de sensoriamento remoto.

Observações:

- ❖ Cada participante deve portar seu notebook com acesso à internet.
- ❖ Material didático e scripts serão disponibilizados previamente ou durante o curso. As atividades práticas serão realizadas preferencialmente nos computadores pessoais dos participantes.
- ❖ Os scripts serão executados em Jupyter Notebook pelo Google Colab (<https://colab.research.google.com/>).
- ❖ Outra possibilidade é realizar as aulas práticas em computadores de uso pessoal. Neste caso o aluno deve levar seu notebook com Python 3.x e as bibliotecas PyTorch, GDAL, Rasterio e scikit-learn previamente instaladas.



PROGRAMA

1. Introdução e Motivação

- 1.1. Sensoriamento Remoto e desafios em análise de imagens
- 1.2. Panorama das técnicas clássicas versus aprendizado profundo
- 1.3. Visão geral de aplicações em mapeamento e monitoramento ambiental

2. Elaboração de Dataset para Imagens de Sensoriamento Remoto

- 2.1. Conceitos fundamentais: dado, amostra, rótulo e classe
- 2.2. Fontes de imagens: satélites ópticos, radar (SAR)
- 2.3. Estratégias de recorte e geração de patches (tiles)
- 2.4. Coleta e vetorização de amostras de referência
- 2.5. Divisão treino, validação e teste (estratégias espacialmente conscientes)
- 2.6. Data augmentation aplicado a imagens geoespaciais
- 2.7. Normalização e pré-processamento de bandas espectrais
- 2.8. Laboratório: construção de dataset com imagens Sentinel-2

3. Classificação Semântica de Imagens

- 3.1. Definição e diferença entre classificação, detecção e segmentação
- 3.2. Segmentação semântica pixel a pixel
- 3.3. Mapas de classes e máscaras de rótulos
- 3.4. Funções de perda para segmentação: Cross-Entropy, Dice Loss, Focal Loss
- 3.5. Métricas de avaliação: Acurácia Global, IoU, F1-Score e Kappa
- 3.6. Desafios específicos do sensoriamento remoto: desbalanceamento de classes, variação sazonal e ruído atmosférico
- 3.7. Laboratório: classificação de cobertura da terra

4. Redes Neurais Convolucionais (CNN)

- 4.1. Fundamentos de redes neurais artificiais de aprendizagem profunda e as suas arquiteturas
- 4.2. Camadas convolucionais: filtros, stride e padding
- 4.3. Estrutura encoder-decoder e conexões de skip
- 4.4. Camadas de pooling e funções de ativação (ReLU, Sigmoid, Softmax)
- 4.5. Batch Normalization e Dropout
- 4.6. Transfer learning e fine-tuning com modelos pré-treinados
- 4.7. Otimizadores: SGD, Adam e estratégias de learning rate scheduling
- 4.8. Laboratório: Seleção de modelos de tarefas de segmentação semântica, configuração do treinamento de modelos, avaliação de desempenho, em PyTorch.